



**GRADO EN ADMINISTRACIÓN Y DIRECCIÓN DE  
EMPRESAS**

**CURSO ACADÉMICO 2019/2020**

**TRABAJO FIN DE GRADO**

**Análisis de red en el fútbol español: Centralidad**  
**Network analysis of Spanish football: Centrality**

**AUTOR: Pedro García Gutiérrez**

**DIRECTOR: Faustino Prieto Mendoza**

**FECHA: Febrero de 2020**

## **AGRADECIMIENTOS**

A mis padres, hermana, y abuela. Que, aunque no me hayan ayudado directamente, probablemente me hayan transmitido la curiosidad para realizar un trabajo como este y también el hecho de intentar desarrollar una idea que me gustara tanto.

A mis amigos, por estar conmigo ya fuera tomando un café, en la biblioteca o donde fuera, escucharme y ayudarme siempre que les he hablado de este trabajo.

A mi tutor, Faustino, por darme la libertad para poder desarrollar una idea propia e innovar, ayudándome en todo lo que he necesitado a la hora de llevarlo a cabo.

## ÍNDICE DE CONTENIDOS

- Resumen .....	5
- Abstract .....	6
1. Introducción .....	7
1.1 Impacto económico .....	7
1.2 Gasto en futbolistas .....	9
2. Datos utilizados en el estudio .....	12
3. Metodología .....	14
4. Medidas de centralidad utilizadas .....	16
4.1 Medidas locales .....	16
4.1.1 Degree (Grado) .....	16
4.1.2 Betweenness (Intermediación).....	17
4.1.3 Closeness (Cercanía) .....	17
4.1.4 Eccentricity (Excentricidad) .....	18
4.1.5 Power Centrality (Centralidad de vector propio).....	18
4.1.6 Transitivity (Clustering).....	19
4.2 Medidas globales .....	19
4.2.1 Minimum and Maximum Eccentricity (Diámetro y radio) .....	19
4.2.2 Average Degree (Grado medio).....	20
4.2.3 Average Path Length (Distancia media ).....	20
4.2.4 Global Transitivity (Clustering global).....	20
5. Resultados .....	21
5.1 Resultados locales .....	22
5.2 Resultados a nivel de equipo. ....	23
5.3 Resultados globales .....	28
6. Conclusiones .....	30
7. Bibliografía .....	32

## ÍNDICE DE ILUSTRACIONES

### Gráficos

- Gráfico 1.1. Impacto económico de LaLiga desglosado .....	8
- Gráfico 1.2. Impacto tractor desglosado .....	9
- Gráfico 1.3. Porcentaje de gasto en salarios por plantilla por club .....	10
- Gráfico 1.4. Evolución del gasto en traspasos de LaLiga .....	11
- Gráfico 5.1. Distribución del grado en la red .....	22
- Gráfico 5.2. Relación entre grado medio y posición final .....	24
- Gráfico 5.3. Clustering medio por equipo .....	25
- Gráfico 5.4. Cercanía media por equipo .....	26
- Gráfico 5.5. Intermediación media por equipo .....	26
- Gráfico 5.6. Posición final y presupuesto de cada club .....	27

### Tablas

- Tabla 2.1. Variables clave en la matriz de datos desglosadas .....	12
- Tabla 2.2. Ejemplo de los datos en transfermarkt.de .....	12
- Tabla 2.3. Ejemplo de un jugador traspasado a mitad de temporada .....	13
- Tabla 3.1. Ejemplo de la matriz de datos .....	14
- Tabla 3.2. Extracto de la matriz de adyacencia .....	15
- Tabla 5.1. Correlación entre las distintas medidas .....	23
- Tabla 5.2. Resultados globales desglosados .....	28

### Imágenes

- Imagen 3.1. Script para crear la matriz de adyacencia .....	14
- Imagen 3.2. Script para crear el gráfico de la red .....	15
- Imagen 4.1. Script para obtener la red Erdos-Renyi .....	16
- Imagen 4.2. Red de Erdos-Renyi .....	16
- Imagen 4.3. Script para obtener el grado .....	17
- Imagen 4.4. Script para obtener la intermediación .....	17
- Imagen 4.5. Script para obtener la cercanía .....	18
- Imagen 4.6. Script para obtener la excentricidad .....	18
- Imagen 4.7. Script para obtener la centralidad de vector propio .....	18
- Imagen 4.8. Script para obtener el clustering local .....	19
- Imagen 4.9. Script para obtener la excentricidad mínima y máxima .....	19
- Imagen 4.10. Script para obtener la media del grado .....	20
- Imagen 4.11. Script para obtener la distancia media .....	20
- Imagen 4.12. Script para obtener el clustering global .....	20
- Imagen 5.1. Representación gráfica de la red completa .....	21
- Imagen 5.2. Representación gráfica de parte de la red .....	21
- Imagen 5.3. Representación gráfica de la red compuesta por el País Vasco ....	28

## RESUMEN

El fútbol en España es una industria de gran importancia a muchos niveles, tanto económicos, como sociales. Este trabajo tiene como finalidad conocer la centralidad en el apartado de Recursos Humanos en el mismo, y en concreto, de los futbolistas que la conforman, a través de su trayectoria profesional. El objetivo ha sido, en primer lugar, conocer los resultados locales y globales, para después poder entender su relación respecto a demás variables importantes en la competición en la que militan los 459 jugadores y 20 equipos objeto del estudio. A partir de datos públicos, se ha creado una base de datos desde cero, con la que más tarde se han realizado todos los cálculos pertinentes. Una vez conocidos los resultados llama la atención que los jugadores más centrales son bastante jóvenes, así como ciertas relaciones entre presupuestos de equipos y la centralidad de sus plantillas. El análisis realizado puede ser de utilidad a cualquier persona interesada en el fútbol, así como a los propios clubes que quieran tener en cuenta los análisis realizados para confeccionar sus plantillas, a la vista de la relación entre la centralidad y los resultados deportivos, o a la Liga de Fútbol Profesional, ya que este trabajo no deja de ser un estudio de la parte más importante de este deporte. Por último, este trabajo es novedoso debido a que, hasta donde llega mi conocimiento, la teoría de redes no ha sido aplicada al aspecto del fútbol referido en este proyecto, si bien sí lo ha sido en otros aspectos del deporte.

## **ABSTRACT**

Football in Spain is an industry whose importance can be seen at many levels, from the economic to the social side of society. This project has the purpose of getting to know, through their professional careers, the centrality of the Human Resources of this industry, in particular, of the footballers that constitute this business. In the first place, the goal has been knowing the results, both local and global, in order to understand their influence on other variables that affect the 459 player, 20 team league. Through data available to everyone, a database has been created from scratch, which has been used to get the required results. Once they were known, the fact that the most central players are quite young stands out, as well as some links between budgets of certain teams and the centrality of their squads. The analysis that has been done in this project could be of use to anyone interested in football, as well as football clubs themselves, as seen by the link between centrality and their performance, which could be useful for the process of arranging their squads, or to the Professional Football League, the reigning body of the competition. Overall, this project is ground-breaking, to the best of my knowledge, since this line of research has not been applied to the part of football it has in this project, although it has been used in different areas of the sport.

## 1. INTRODUCCIÓN

El fútbol es el deporte por excelencia en España, y lo mismo ocurre en gran parte del Mundo. Más de 3.500 millones de personas vieron el Mundial de Rusia en 2018, y más de 1.100 millones de personas vieron la final (FIFA, 2018). Este hecho por sí solo ya explica la importancia a nivel mundial de este deporte, teniendo en cuenta que esos datos representan, más del 50% de la población mundial, y más de un 15% de la misma, respectivamente.

Por tanto, el fútbol, además de un deporte, es un fenómeno social, con un impacto en la sociedad en gran variedad de formas, y que, además, supone una gran industria en sí misma tanto a nivel nacional, representada por LaLiga<sup>1</sup>, que es la sociedad que gestiona todo el fútbol profesional en España, que será objeto de análisis de este trabajo, como a nivel mundial.

Dentro de esta industria los claros protagonistas son los futbolistas, aquellos que todos conocemos y que reciben gran parte de la atención que genera todo el sector. Comprenderemos la importancia del fútbol en España, y también la importancia de los futbolistas dentro del sector, que dejan de ser simples empleados de los clubes en los que militan para convertirse en iconos conocidos a nivel mundial.


### 1.1. IMPACTO ECONÓMICO

Todos conocemos que el fútbol está presente en la sociedad a todos los niveles. Como ya he mencionado anteriormente, más de medio Mundo vio el último mundial. A su vez, esto se traduce en un importante impacto económico, que analizaremos en este caso a nivel nacional.

Como refleja PricewaterhouseCoopers (2018) en su informe, el impacto económico se determina por los impuestos tributados, el empleo creado, y la propia producción. El impacto económico es de 4 tipos, directo, indirecto, inducido, y tractor. El total de LaLiga en 2017 fue de más de 15.688 millones de euros, de los cuales, solo 3.010 son de forma directa, es decir, generados directamente por LaLiga. El resto del impacto se divide en impacto indirecto, inducido y tractor. Por impacto indirecto entendemos el impacto que genera en la cadena de suministros, como proveedores, que en este caso es de 5.594 millones de euros. Con impacto tractor nos referimos a cómo influye el fútbol a sectores relacionados, como la hostelería o el sector hotelero, generando un impacto de 3.998 millones de euros. El impacto inducido es el generado por el impacto en las condiciones de los hogares a los que influyen el impacto indirecto e inducido, suponiendo 3.086 millones de euros. A nivel nacional, esto supone un impacto del 1,37% del PIB. A continuación, vemos un gráfico en el que se desglosa la importancia relativa de cada tipo de impacto.

---

<sup>1</sup> Cuando hablamos de LaLiga nos referimos a la sociedad que regula la competición futbolística en España, en concreto la Primera División, que es la que concierne al trabajo.

**Gráfico 1.1. Impacto económico de LaLiga desglosado**


Fuente: elaboración propia a partir de datos de PwC (2018)

Para comprender mejor el alcance de este sector, vamos a profundizar en el impacto tractor, que es el generado por arrastre en sectores relacionados. Como ya hemos mencionado anteriormente, el efecto que genera en otros sectores es de 3.998 millones de euros, de los cuales gran parte se reflejan en lo denominado “día de partido”, es decir, los gastos que se realizan que no son propiamente la entrada al partido. Estos incluyen el gasto en bares para ver partidos y también posibles gastos en turismo de aquellos que viajan para ver a su equipo.

El sector de las telecomunicaciones es el siguiente más beneficiado. En este apartado hay 2 grandes grupos, la TV de pago y los medios de comunicación. En lo que concierne a la TV de pago, el fútbol suele ofrecerse en paquetes junto con líneas móviles y el internet del hogar, siendo el principal reclamo de las compañías de telecomunicaciones para obtener clientes. Un 58% de clientes tienen contratado el fútbol en sus paquetes, y un 41% no lo habrían contratado de no incluir fútbol. A los medios de comunicación les beneficia a un nivel similar. Una de las principales fuentes de ingresos de los medios de comunicación es la publicidad, y al ser el fútbol el deporte más consumido, la relación entre este deporte y los ingresos es directamente proporcional.

Los 2 últimos sectores ampliamente influenciados por el balompié son el de los juegos de azar y apuestas, y el de los videojuegos. Como afirma Europapress (2018), 4 de los 10 videojuegos más vendidos son de temática futbolística, además de que el sector de los videojuegos de forma competitiva está creciendo ampliamente también en España. En lo que tiene que ver con los juegos de azar y casas de apuestas, estos movieron más de 3.000 millones de euros en la temporada 2016-17, siendo digno de mencionar a su vez que prácticamente todos los equipos de Primera y Segunda División cuentan con una casa de apuestas entre sus patrocinadores. A continuación, vemos un gráfico con los distintos componentes del impacto tractor desglosados por el nivel de importancia sobre el total.



**Gráfico 1.2. Impacto tractor desglosado**

Fuente: elaboración propia a partir de datos de PwC (2018)

Por último, el impacto a nivel laboral es notable. El empleo total creado por este sector asciende a 184.626 puestos de trabajo. De la misma forma que con el impacto económico, este se divide en impacto directo, inducido, indirecto y tractor. De ellos, 47.674 se crean directamente por parte de LaLiga, lo que significa que, por cada empleo creado de forma directa, se crean 4 más. La cifra total de empleos creados supone un 0,98% de la población ocupada en el momento en el que se realizó el estudio.

Además del impacto tanto laboral como económico en los sectores ya analizados, cabe destacar que sectores como el del videojuego se encuentran en crecimiento, que ya genera más de 1.500 millones de euros, o las casas de apuestas, que están presentes a una escala cada vez mayor a nivel nacional.


## 1.2. GASTO EN FUTBOLISTAS

Una vez conocido el impacto que genera el fútbol en España, es necesario conocer la importancia de los futbolistas dentro de la industria, que son el aspecto a analizar de este trabajo. En perspectiva, los futbolistas no son el grupo de empleados más numeroso de un club de fútbol, solamente suponen entre 20 y 30 empleados por club.

Para comprender la importancia de los futbolistas dentro de los clubes en los que se encuentran, y, por ende, a nivel económico, es necesario conocer los salarios que reciben. En lo que concierne a los clubes objeto del estudio, no todos tienen la misma capacidad económica, habiendo especialmente 2 muy por encima del resto, como el FC Barcelona y el Real Madrid CF, y otros equipos muy pequeños como el CA Osasuna. Por ello hemos comparado el gasto en salarios de la plantilla con el total de ingresos del club. Como vemos en el gráfico, la media se sitúa en un 52,5%, con equipos que sobrepasan ampliamente el 60%, y otros ligeramente por debajo del 40% en el otro extremo. Para este cálculo solo se ha tenido en cuenta el gasto en la plantilla, sin incluir el gasto en la directiva ni en miembros del cuerpo técnico como entrenadores o

preparadores físicos. Considerando que un porcentaje de gasto en personal en una empresa se podría situar sobre el 30% de los ingresos totales, como refleja Impulsapopular (2014), vemos que los futbolistas tienen una importancia vital en sus empresas, que son los clubes en este caso. A continuación, vemos un gráfico en el que se detalla el porcentaje de gasto en salarios de plantilla de los equipos que militaron en la Primera División en la temporada 2016-17.

**Gráfico 1.3. Porcentaje de gasto en salarios de plantilla por club**




Fuente: elaboración propia a partir de datos contables de cada club

La otra variable económica que nos ayuda a explicar la importancia de los futbolistas es la importante suma de dinero que supone el traspaso de un jugador de un club a otro, algo que no deja de ser el movimiento de un trabajador de una empresa a otra, con un club pagando al otro para que le traspase los derechos sobre ese jugador. Además del propio derecho que supone que un jugador juegue para un club en vez de otro, estos derechos también suelen incluir cláusulas en las que se incluyen retenciones sobre los derechos de imagen que van a parar al club, así como cláusulas sobre posibles traspasos a otros clubes. Otro claro ejemplo es la importancia de los representantes de futbolistas, suponiendo este otro sector como tal. En este caso, los clubes españoles han desembolsado unos 145 millones de euros en comisiones dirigidas a los agentes representantes de futbolistas en el periodo que abarca desde 2013 a 2018.

Como vemos en el gráfico a continuación, la suma económica total de traspasos de los equipos de Primera División en los últimos 10 años sigue una línea general ascendente, pasando de 262 millones de euros en la temporada 2010-11, a 1.319 en la actual temporada, si bien este último resultado puede ser algo extraordinario a espera de ver como evoluciona, la tendencia es ligeramente ascendente en la última década. Además, el gasto estaba muy centralizado en el Real Madrid y el FC Barcelona, que abarcaban un 80% del gasto total. Sin embargo, ahora solamente el 43,5% del gasto es propio de ellos, es decir, en LaLiga el gasto se está distribuyendo de una manera más equitativa entre todos los equipos que la conforman.

**Gráfico 1.4. Evolución del gasto en traspasos de LaLiga**



Fuente: elaboración propia a partir de datos de Primetimesport (2019)

El fútbol en general, y los futbolistas en particular, tienen una importancia notable en la economía nacional, en el caso general, y dentro de los clubes, en el caso particular de los futbolistas.

En relación a trabajos previos de fútbol en los que se ha utilizado la teoría de redes, resaltar el trabajo de Buldú et al. (2019), con el que se analizó la centralidad del FC Barcelona de la década pasada a través de la red creada por sus pases en los partidos. Destacar también el trabajo realizado en otros países como el realizado por Korte et al. (2019), con el que estudiaron la competición alemana a través de la teoría de redes, utilizando las dinámicas que se crean en un partido.

En este trabajo, utilizaré la teoría de redes para estudiar la centralidad en el fútbol en un nivel distinto al que, hasta donde llega mi conocimiento, ha sido realizado hasta el momento, que es a un nivel de Recursos Humanos, y no al nivel más directo del fútbol, que es el desarrollo de un partido.

En los apartados siguientes, se describen los datos utilizados en el estudio, la metodología seguida, así como las medidas utilizadas, para finalizar con los resultados obtenidos y las conclusiones.

## 2. DATOS UTILIZADOS EN EL ESTUDIO

Para realizar este estudio sobre la red compuesta por los jugadores de la Primera División española en la temporada 2018-19 ha sido necesario crear una matriz de datos con toda la trayectoria de los jugadores, como aparece detallado en la siguiente tabla.

**Tabla 2.1. Variables clave en la matriz de datos desglosadas**

Total de jugadores	459
Años en el estudio	20
Clubos analizados	20
Clubos que aparecen en el estudio	511

Fuente: elaboración propia

Han sido considerados solamente los jugadores con ficha del primer equipo, es decir, aquellos jugadores cuyo dorsal se encuentra entre el número 1 y el número 25, ambos incluidos. Todos estos jugadores se encontraban en sus equipos a fecha de 25 de abril de 2019. Conformando todos los futbolistas un total de 459 actores en la red, extendiéndose sus trayectorias desde el año 1999, en el caso del jugador más longevo, hasta la fecha ya mencionada.

Los jugadores son los de la Primera División española, pero para la trayectoria se ha tenido en cuenta todos los equipos por los que hayan podido moverse en su carrera, es decir, no sólo equipos españoles, si no también extranjeros. Los clubes son los que completaron la temporada 2018-19, siendo todos los clubes tratados con la misma importancia.

Los datos de cada jugador han sido obtenidos de la página web alemana "transfermarkt.de", en la que aparecen de forma detallada, entre otras muchas cosas, la trayectoria de cada jugador, incluyendo fechas de traspasos entre distintos equipos, datos indispensables para este análisis. Asimismo, datos personales como la edad o la nacionalidad no han sido incluidos. A continuación, vemos un ejemplo de la información relativa a traspasos de cualquier jugador, Ezequiel Garay en este caso.

**Tabla 2.2. Ejemplo de los datos en transfermarkt.de**

HISTORIAL DE FICHAJES						
Temporada	Dato	Último club	Nuevo club	Valor	Coste	
16/17	31/08/2016	 Zenit	 Valencia CF	20,00 mill. €	24,00 mill. €	>
14/15	01/07/2014	 Benfica	 Zenit	20,00 mill. €	6,00 mill. €	>
11/12	01/07/2011	 Real Madrid	 Benfica	10,00 mill. €	5,50 mill. €	>
08/09	30/06/2009	 Racing	 Real Madrid	12,00 mill. €	Fin de préstamo	>
08/09	01/08/2008	 Real Madrid	 Racing	10,00 mill. €	Préstamo	>
08/09	01/07/2008	 Racing	 Real Madrid	10,00 mill. €	10,00 mill. €	>
05/06	01/01/2006	 Newell's	 Racing	300 miles €	1,40 mill. €	>
03/04	01/01/2004	 Newell's II	 Newell's	-	-	>
Coste total :					46,90 mill. €	

Fuente: transfermarkt.de

Al tratar una cantidad tan grande de jugadores, es posible que los nombres de algunos de ellos puedan parecer iguales entre ellos e inducir a error, para evitar este problema, a cada jugador le ha sido asignado un número, así en el caso de que haya 2 jugadores

con el mismo nombre, al cambiar su forma de identificación por un número, el problema de identificación queda eliminado.

El mismo problema ocurre con los equipos por los que hayan pasado los jugadores. Sus nombres también pueden ser similares y por lo tanto inducir a error. Para eliminar esta inconveniencia también se le ha asignado a cada equipo que aparece en la base de datos un número, obteniendo por tanto una base de datos compuesta por números, eliminando caracteres alfabéticos.

En el caso de los futbolistas, estos no siempre concluyen la temporada con el equipo con la que la empezaron, es decir, pueden ser traspasados a otro equipo a mitad de temporada. Por ello, cuando eso ocurre, se añade una nueva entrada de ese jugador, constando por tanto que ha estado en 2 equipos en la misma temporada, o incluso en 3 si la situación se diera.

**Tabla 2.3. Ejemplo de un jugador traspasado a mitad de temporada**

Nombre	Número	2015-16	2016-17	2017-18	2018-19	
Philippe Coutinho	100	87	87	87	87	5
Philippe Coutinho	100				5	

Fuente: elaboración propia

Del mismo modo, es frecuente entre equipos de fútbol adquirir un jugador, e inmediatamente cederlo a otro equipo, en esos casos se ha tenido en cuenta el equipo en el que realmente ha participado el jugador, es decir, en este caso al equipo al que fue cedido.

A su vez, gran parte de los futbolistas ocupan parte de su carrera en filiales, que en este caso son parte del mismo club, pero a un nivel futbolístico inferior. Por ello, los filiales claramente identificados como el segundo equipo del club han sido considerados en la base de datos. Por ejemplo, el FC Barcelona B sí ha sido considerado, mientras que otros como el Manchester City Sub23 no.

A partir de todo lo anteriormente mencionado, y con las condiciones ya expuestas se ha creado una matriz de adyacencia. En ella se ha explicado a partir de una variable binaria si un jugador ha coincidido en su carrera con otro. Si han coincidido, el valor será 1, mientras que si no han coincidido el valor será 0. Por tanto, la matriz tendrá una diagonal 0, ya que evidentemente es irreal considerar que un jugador ha coincidido consigo mismo.

Una vez obtenida la matriz de adyacencia es posible analizar la centralidad de la red creada. En la que los nodos de la misma son los jugadores, y están unidos entre sí aquellos que hayan coincidido en su carrera futbolística.

### 3. METODOLOGÍA

Como ya ha sido mencionado, la matriz de datos consistía en todos los jugadores con sus respectivas trayectorias profesionales, siendo ambos sustituidos por números para facilitar su tratamiento y eliminar posibles errores al manejar la matriz de datos. Por tanto, el resultado final de la matriz de datos consiste en jugadores y equipos identificados con números. Un ejemplo es el que vemos a continuación, Mikel Rico, número 17 en la matriz de datos, y cada equipo identificado a su vez con un número propio.

**Tabla 3.1. Ejemplo de la matriz de datos**

Nombre	Número	2012-13	2013-14	2014-15	2015-16	2016-17	2017-18	2018-19
Mikel Rico	17	38	1	1	1	1	1	1

Fuente: elaboración propia

En toda la matriz de datos se repite el mismo formato. En este caso el 17 es el número identificativo del jugador, y los demás números son identificativos de distintos clubes. El número 1 representa al Athletic Club de Bilbao, mientras que el 38 representa al Granada CF.

A partir de ahí es necesario crear la matriz de adyacencia que permite dibujar la red, y, por ende, realizar todos los cálculos que serán analizados. Tanto para crear la matriz de adyacencia como para medir la centralidad de la red el programa utilizado es R. A continuación, los comandos utilizados para crear la matriz de adyacencia a partir de la base de datos.

**Imagen 3.1. Script para crear la matriz de adyacencia**

```

4 #
5 Database<-read.table("datos.csv",header=T,sep=";")
6 View(Database)
7 colnames(Database)<-c("Jugador",1999:2019)
8 View(Database)
9 jugadores<-max(Database[,1])
10 jugadores
11 Adj<-matrix(0,jugadores,jugadores)
12 View(Adj)
13 class(Adj)
14 #####
15 for (year in 2000:2019){
16   aux<-year-1999+2
17   data1<-Database[c(1,aux)]
18   data2<-data1[!is.na(data1[,2]),]
19   n<-nrow(data2)
20   n
21   if (n>1){
22     for (i in 1:(n-1)){
23       for (j in (i+1):n){
24         if(data2[i,2]==data2[j,2]){
25           aux1<-data2[i,1]
26           aux2<-data2[j,1]
27           Adj[aux1,aux2]=1;
28           Adj[aux2,aux1]=1;

```

Fuente: elaboración propia

En primer lugar, conseguimos que R reconozca y lea la matriz de datos creada, para después eliminar aquellas filas que aparezcan repetidas. Esto ocurre cuando un jugador está en más de 1 equipo en la misma temporada. Y, por último, una vez no hay ningún jugador repetido por ello, se crea la matriz de adyacencia, que consta de 1 y 0.

Pero es necesario crear una red, es decir, un gráfico a partir de la matriz de adyacencia. R comprende muchos paquetes dependiendo de lo que se quiera calcular con el

programa. En este caso el paquete utilizado ha sido el paquete “igraph”. A continuación, vemos los comandos utilizados para poder crear el gráfico.

**Imagen 3.2. Script para crear el gráfico de la red**

```
56 library(igraph)
57 FootballNetig<-graph.adjacency(Adj,mode="undirected",weighted=NULL)
58 zclass(FootballNetig)
59 plot(FootballNetig)
```

Fuente: elaboración propia

Con estos 4 comandos conseguimos que se traten todos los datos como un gráfico, permitiéndonos crear uno correspondiente a la red. En concreto, una red no dirigida, como indica el comando número 57, y por último reflejar la matriz de adyacencia en una red. Una vez considerados los datos como un gráfico, es posible también realizar todos los cálculos necesarios. A continuación, vemos un extracto de la matriz de adyacencia.

**Tabla 3.2. Extracto de la matriz de adyacencia**

	V1	V2	V3	V4	V5	V6	V7	V8	V9	V10	V11	V12	V13
1	0	1	1	1	1	1	1	1	1	1	1	1	1
2	1	0	1	1	1	1	1	1	1	1	1	1	1
3	1	1	0	1	1	1	1	1	1	1	1	1	1
4	1	1	1	0	1	1	1	1	1	1	1	1	1
5	1	1	1	1	0	1	1	1	1	1	1	1	1
6	1	1	1	1	1	0	1	1	1	1	1	1	1
7	1	1	1	1	1	1	0	1	1	1	1	1	1
8	1	1	1	1	1	1	1	0	1	1	1	1	1
9	1	1	1	1	1	1	1	1	0	1	1	1	1
10	1	1	1	1	1	1	1	1	1	0	1	1	1
11	1	1	1	1	1	1	1	1	1	1	0	1	1

Fuente: elaboración propia

El extracto utilizado corresponde a los 11 primeros jugadores de la red y aparece la diagonal de valor 0, y en los casos en los que han coincidido aparece un 1.

## 4. MEDIDAS DE CENTRALIDAD UTILIZADAS

La centralidad de una red puede ser medida de una gran variedad de formas, y acorde a eso será analizada en este trabajo, para ello utilizaremos distintas medidas de centralidad, tanto locales, para evaluar a los actores de la red, como globales, para poder juzgar la red en su totalidad.


**Imagen 4.1. Script para crear la red Erdos-Renyi**

```
85 # n = number of nodes, m = the number of edges
86 erdos.gr <- sample_gnm(n=10, m=24)
87 plot(erdos.gr)
```

Fuente: elaboración propia

Con el objeto de explicar cada medida de una forma más sencilla de comprender, se ha seguido el modelo Erdos-Renyi, creando una red con los nodos y enlaces deseados. En este caso es una red de 10 nodos, y 24 enlaces entre ellos, es decir, mucho más fácil de comprender que la red analizada, que cuenta con 459 nodos. A continuación, se muestra el gráfico de esta red.

**Imagen 4.2. Red de Erdos-Renyi**



Fuente: elaboración propia

### 4.1. MEDIDAS LOCALES

En primer lugar, utilizaremos medidas de centralidad locales, con las que, a partir de la red, obtendremos un valor individual para cada nodo con todas las medidas que utilizemos. Se parte de la red completa, y se consigue un valor con el que evaluar cada nodo por separado con las distintas medidas que utilizemos.

#### 4.1.1. Degree (Grado)

En una red los nodos están conectados entre sí. De ahí surge esta forma de medir, que consiste en contabilizar con cuántos está conectado cada nodo. Es la forma más simple de medir la centralidad y también la más local, ya que solo analiza la influencia más



directa de cada actor, que es las vinculaciones que tiene en su entorno más cercano. El comando utilizado para calcular en R el grado aparece bajo estas líneas.

**Imagen 4.3. Script para obtener el grado**

```
> degree(erdos.gr)
[1] 6 3 4 6 5 5 5 3 6 5
```

Fuente: elaboración propia

Como vemos, la interpretación es muy simple, siendo en este caso los nodos menos centrales el número 2 y el 8, estando unidos a otros 3 nodos cada uno, mientras que el número 1, 4, y 9, son los más centrales según esta medida, estando unidos cada uno de ellos a otros 6 nodos.

#### 4.1.2. Betweenness (Intermediación)

Uno de los problemas del grado es que solo se centra en la influencia más directa de cada nodo, mientras que la intermediación tiene en cuenta más factores. Esta medida tiene en cuenta los caminos mínimos entre cualquier par de actores, y la presencia en esos caminos. Es decir, si la intermediación es alta, el nodo estará muy involucrado en los caminos de los demás componentes de la red. Aquellos que cuentan con una intermediación alta pueden desempeñar un papel muy importante de conexión entre grupos distintos muy unidos de la red, pudiendo ser llamados "porteros", por ser quienes controlan el flujo de información entre distintas partes de la red.

**Imagen 4.4. Script para obtener la intermediación**

```
> betweenness(erdos.gr)
[1] 5.1666667 0.0000000 0.2500000 3.0833333 1.9166667 2.8333333 1.5000000
[8] 0.5833333 3.7500000 2.9166667
```

Fuente: elaboración propia

Como vemos, el nodo número 2 es el menos intermedio de la red, teniendo un valor de 0 porque ninguno de los caminos más cortos entre cualquier par de nodos de la red pasa por él, mientras que el 1 vuelve a ser el más central, debido a que es por el que más caminos pasan. Sin embargo, el grado del 4 y el 9 es de 6, mientras que la intermediación del 9 es mayor, por lo que, si bien el mayor grado de un nodo sobre el de otro es probable que se traduzca en una mayor intermediación, no necesariamente tiene que ser de esa forma.

#### 4.1.3. Closeness (Cercanía)

La siguiente medida utilizada es la cercanía, que valora lo cerca del núcleo que está un nodo, y lo poco lejos que esté del centro, a diferencia del grado, que tiene en cuenta la conexión más directa con el resto de la red, y de la intermediación, que tiene en cuenta lo intermedio que es un nodo. Con la suma de las distancias entre cada nodo se conoce la lejanía de cada uno, y con su inversa se conoce la cercanía.

**Imagen 4.5. Script para obtener la cercanía**

```
> closeness(erdos.gr)
[1] 0.08333333 0.06250000 0.06666667 0.08333333 0.07692308 0.07692308
[7] 0.07692308 0.06666667 0.08333333 0.07692308
```

Fuente: elaboración propia

A partir de los resultados vemos que los nodos 1, 4, y 9 son los que cuentan con un valor de cercanía mayor, mientras que el 2 es el menos cercano. Esta medida confirma lo que las anteriores medidas nos indicaban en cuanto a qué nodos son los más y menos centrales. Sin embargo, nodos como el 7, tienen una centralidad mayor siguiendo otras medidas como la intermediación.

#### 4.1.4. Eccentricity (Excentricidad)

La siguiente medida es la excentricidad, que utiliza también las distancias entre nodos para su cálculo, si bien a diferencia de la cercanía que utilizaba la suma de las distancias entre nodos, con la excentricidad se utiliza la distancia máxima entre ellos. Cuanto menor sea la excentricidad, mayor será la centralidad del nodo

**Imagen 4.6. Script para obtener la excentricidad**

```
> eccentricity(erdos.gr)
[1] 2 3 3 2 2 2 2 2 2
```

Fuente: elaboración propia

Al tratarse de una red tan pequeña la excentricidad entre distintos nodos iba a ser muy similar, aun así, los nodos 2 y 3 cuentan con una excentricidad de 3, mientras que los demás tienen una excentricidad de valor 2. Es decir, para los nodos 2 y 3, la distancia máxima respecto a cualquier otro nodo es de 3, mientras que los demás están como máximo, a 2 nodos de distancia de cualquier otro.

#### 4.1.5. Power Centrality (Centralidad de vector propio)

Con la centralidad de vector propio se pasa a tener en cuenta la calidad de las conexiones más allá de la cantidad, es una evolución del concepto del grado ya que se pasa a la idea de que no todas las conexiones son de la misma importancia. En esa línea, existen 2 maneras de evaluar la centralidad siguiendo el modelo de Bonacich, la primera asumiendo que los actores tienen mayor importancia al estar conectados a actores muy centrales, y la segunda asumiendo lo contrario, es decir, que se adquiere mayor importancia al estar conectado a actores poco centrales.

**Imagen 4.7. Script para obtener la centralidad de vector propio**

```
> power_centrality(erdos.gr, exponent = 1)
[1] -1.4075662 -0.6496459 -0.7579203 -0.7579203 -1.0827432 -0.3248230 -1.0827432 -1.0827432 -1.6241149
[10] -0.4330973
> power_centrality(erdos.gr, exponent = -1)
[1] 1.0540926 0.0000000 -0.3513642 1.4054567 1.0540926 0.7027284 1.7568209 0.7027284 0.7027284
[10] 1.0540926
```

Fuente: elaboración propia

Considerando que la centralidad recae sobre estar conectado a actores muy centrales, tomamos un exponente positivo, mientras que, si consideramos que la importancia existe en el hecho de estar conectado a actores poco centrales, tomamos un exponente negativo, y en el caso de que todos los resultados sean negativos, tomamos el valor absoluto como dato. Como vemos, los resultados son totalmente opuestos en las 2 consideraciones. Nodos como el 2 son poco centrales en ambas evaluaciones, mientras que el nodo 7 es el más central si tenemos en cuenta su unión con actores poco centrales, y es el nodo 9 el más central al contar con que esté vinculado a otros nodos muy centrales.

#### 4.1.6. Transitivity (Clustering)

En las redes suele pasar que los nodos conectados con un mismo nodo, también están conectados entre sí, ese fenómeno es conocido como clustering, y también es una medida de centralidad. Por lo que mediremos la probabilidad de que los nodos con los que un nodo esté conectado, estén conectados entre sí, creando clusters.

**Imagen 4.8. Script para obtener el clustering local**

```
> transitivity(erdos.gr, type = "local")
[1] 0.4000000 1.0000000 0.8333333 0.5333333 0.6000000 0.4000000 0.6000000 0.3333333 0.4666667
[10] 0.5000000
```

Fuente: elaboracion propia

A diferencia de los resultados obtenidos con otras medidas, el nodo 2 resulta el más central ya que la probabilidad de que los nodos conectados con ese nodo estén conectados entre sí es del 100%, algo lógico si vemos que es el que tiene, por ejemplo, menor grado. Sin embargo, el número 1 es de los que menos clustering genera, a pesar de ser de los que mayor grado tiene.

## 4.2. MEDIDAS GLOBALES

Para valorar la red en su totalidad utilizaremos las medidas globales, que suelen tener relación directa con medidas locales, es decir, que para su cálculo se parte de ellas, aunque también hay medidas que no tienen nada que ver con ellas.

### 4.2.1. Minimum and Maximum Eccentricity (Diámetro y radio)

En primer lugar, son utilizadas las medidas de diámetro y radio, que derivan directamente de la medida local de excentricidad. El diámetro se corresponde con el valor máximo de excentricidad de la red, mientras que el radio equivale a el valor mínimo de excentricidad de la misma. En esta red, el diámetro es 3, que es la excentricidad más alta, y el radio es 2, que equivale al valor de excentricidad más bajo.

**Imagen 4.9. Script para obtener la excentricidad mínima y máxima**

```
> max(eccentricity(erdos.gr))
[1] 3
> min(eccentricity(erdos.gr))
[1] 2
```

Fuente: elaboración propia

#### 4.2.2. Average Degree (Grado medio)

El grado medio, al ser esta red una red no dirigida, se corresponde con la media aritmética del grado de cada uno de los nodos.

**Imagen 4.10. Script para obtener la media del grado**

```
> mean(degree(erdos.gr))
[1] 4.8
```

Fuente: elaboración propia

Como vemos, cada nodo está conectado, de media, con 4, 8 nodos.

#### 4.2.3. Average Path Length (Distancia media)

Con esta medida se va a obtener la distancia media entre cualquier par de nodos, que permitirá ver si la red analizada está muy concentrada o más dispersa. Por ello un valor bajo implicará que la red tiene una centralidad alta.

**Imagen 4.11. Script para obtener la distancia media**

```
> average.path.length(erdos.gr)
[1] 1.488889
```

Fuente: elaboración propia

En este caso, al tratarse de una red especialmente pequeña el valor es bajo. Sin embargo, si en redes más grandes la distancia media tiene un valor bajo significará que todos los nodos están cerca unos de otros.

#### 4.2.4. Global Transitivity (Clustering global)

El clustering se puede medir de 2 formas, de forma local, como hemos hecho anteriormente, y también de forma global, considerando la red en su totalidad. En este caso el cálculo no es a partir de la media aritmética de los coeficientes locales de cada nodo, si no que se toman todos los triángulos que existen en la red. Estos triángulos pueden ser abiertos, en la que 2 de los 3 nodos están conectados entre sí, o cerrados, en la que los 3 nodos están unidos entre sí. Con lo que obtenemos la probabilidad de que un triángulo sea cerrado.

**Imagen 4.12. Script para obtener el clustering global**

```
> transitivity(erdos.gr, type = "global")
[1] 0.5257732
```


Fuente: elaboración propia.

Este resultado nos indica que el 52,5% de los triángulos que existen en la red están cerrados, con sus miembros conectados entre sí.

## 5. RESULTADOS

Con todos los datos obtenidos y utilizando R, creamos la red a analizar. Al contar con 459 nodos, los enlaces son en su mayoría imposibles de ver. A continuación vemos la representación gráfica de la red completa, con los 459 jugadores y 20 equipos que la constituyen.


**Imagen 5.1. Representación gráfica de la red completa**



Fuente: elaboración propia

Para comprender mejor la centralidad de la red, además de las formas anteriormente mencionadas, también será analizada a nivel de equipos, relacionando los resultados obtenidos con otras variables, así como con el presupuesto de cada club, y su desempeño en la competición. Para poder ver mejor una representación gráfica de la red vamos a utilizar parte de la misma y verla.

**Imagen 5.2. Representación gráfica de parte de la red**




Fuente: elaboración propia

En esta red solamente se utilizan los datos de 3 de los 20 equipos, consiguiendo una red, que utilizamos de modo ilustrativo para poder ver una representación clara, al contrario que la red completa en la que no se distingue a simple vista.

## 5.1. RESULTADOS LOCALES

A partir de los cálculos realizados sobre la red, vemos que el jugador que ha jugado con más jugadores en su carrera es Munir El Haddadi, que ha coincidido con otros 77 jugadores de los presentes en Primera. Si vemos los 10 jugadores con mayor grado, vemos un patrón común y es el de un jugador que ha pasado por una variedad de equipos en los últimos años a través de una carrera relativamente dilatada. Mientras que en este caso los 2 jugadores con mayor grado son 2 jugadores que provienen de las mayores canteras del fútbol español, que son las del Real Madrid y el Fútbol Club Barcelona, que utilizan las cesiones a otros clubes como parte de su formación, siendo Munir y Denis Cheryshev, el segundo jugador con mayor grado, jugadores aún jóvenes. De la misma forma, aquellos con menor grado son aquellos que se incorporaron en la misma temporada que es objeto del análisis y por tanto solo han estado en 1 equipo durante 1 temporada.

**Gráfico 5.1. Distribución del grado en la red**



Fuente: elaboración propia

En cuanto al clustering local, vemos que los jugadores recién incorporados a la competición tienen un porcentaje de clustering del 100%, ya que solo han coincidido con un grupo de jugadores en su estancia en la categoría. Destaca también que el jugador con menor clustering es Denis Cheryshev, que es el segundo con mayor grado de la red. Al comparar esta medida con otras utilizadas, observamos, en primer lugar, que la correlación con el grado es fuertemente negativa. En otras palabras, cuanto mayor es el grado, menor es el clustering. Lo mismo ocurre con la intermediación, cuya correlación es muy negativa, aquellos con un clustering del 100% tienen una intermediación de 0, ya que no están entre ningún camino.

A colación del anterior párrafo, vemos que, de los 15 jugadores con mayor intermediación, 10 de ellos se encuentran entre los 15 que mayor grado tienen, siendo también Munir el jugador con mayor intermediación. Asimismo, el perfil de jugador se repite, un jugador con experiencia, con una amplia trayectoria en los clubes analizados. En la línea del dato ya mencionado, la correlación entre esas medidas es positiva prácticamente al 100%, con un coeficiente de correlación positivo de 0,91.

La siguiente medida utilizada es la cercanía, en la que el jugador con mayor cercanía es Rubén Sobrino, que encaja con el perfil de Munir, es un jugador joven, que se ha

movido entre equipos que no han descendido a la Segunda División y por ello ha conseguido una posición central en la red. En la misma línea de las anteriores medidas, la correlación con el grado y la intermediación es muy fuerte positivamente. Con el grado es de 0,87; y con la intermediación es de 0,78. Por ello, el grupo de jugadores muy centrales y poco centrales sigue siendo, en líneas generales, el mismo.

La última medida utilizada ha sido la centralidad de vector propio, valorando tanto la relación con nodos muy centrales como con nodos poco centrales. Ambas ofrecen unos resultados distintos a los de las demás medidas. El jugador con mayor centralidad teniendo en cuenta si está conectado a jugadores muy centrales es Gabriel Mercado, del Sevilla CF. Dentro de los 15 con mayor centralidad según este criterio, vemos que ninguno cuenta con un valor destacable en las otras medidas utilizadas, fruto de tener en cuenta un criterio que no incluye directamente ninguna de ellas.

Lo mismo ocurre si valoramos que estén conectados a jugadores poco centrales. En este caso el jugador más central es Ezequiel Ávila, de la SD Huesca. Aquí ocurre el mismo fenómeno, en líneas generales ningún jugador, tanto con una centralidad alta, como baja, tiene valores destacables en otras medidas utilizadas.

Para reforzar esta idea ha sido calculada la correlación entre la centralidad de vector propio respecto a otras medidas. Vemos que entre las 2 formas de medirla no hay correlación alguna. Resultado que es lógico ya que al ser una red tan amplia un jugador puede estar conectado a jugadores muy centrales y también a jugadores poco centrales. Respecto al clustering, la correlación es ligeramente negativa, y ligeramente positiva respecto al grado. Pero en ambos es insignificante la correlación.

En general, los jugadores más centrales se repiten gracias a la fuerte correlación entre variables que hace que los resultados varíen ligeramente entre sí, pero mantengan una línea común.

**Tabla 5.1. Correlación entre las distintas medidas**

Correlación Grado/Cercanía	0,87335752
Correlación Grado/Intermediación	0,9117765
Correlación Clustering/Intermediación	-0,79498443
Correlación Intermediación/Cercanía	0,78239945
Correlación Grado/Clustering	-0,87453854
Correlación Bonacich	0,00591907
Correlación Clustering/Bonacich -0,5	-0,02984871
Correlación Clustering/Bonacich +0,5	-0,06770908
Correlación Grado/Bonacich -0,5	0,00462227
Correlación Grado/Bonacich +0,5	0,08156441

Fuente: elaboración propia

## 5.2. RESULTADOS A NIVEL DE EQUIPO

Otra forma de analizar la centralidad es centrar el análisis a nivel de los equipos, es decir, a un nivel intermedio entre las medidas locales y las globales, pudiendo de esta




forma relacionar los resultados con otros aspectos relacionados con el sector que es objeto de estudio, el fútbol.

Una forma de distinguir a unos equipos de otros es por el nivel de éxito que consigan. En España los clubes más exitosos son el Atlético de Madrid, el FC Barcelona, y el Real Madrid. A nivel nacional el FC Barcelona es el claro dominador en los últimos años, club que vemos que tiene un nivel de clustering medio muy alto, así como un grado medio muy bajo. Es decir, los jugadores del FC Barcelona han jugado con pocos jugadores, y están, en cierta medida, aislados del resto. Lo mismo ocurre con el Real Madrid, claro dominador del fútbol europeo y mundial en el último lustro, que tiene un grado medio muy bajo. El club con un grado medio más bajo es el Atlético de Madrid, que después de Real Madrid y FC Barcelona es el club más grande en España.

Además de contar con un grado medio bajo, los 3 cuentan con una cercanía media muy baja, que refuerza lo que indican tanto el grado medio con un valor bajo y un clustering medio con un valor alto. En el caso del Atlético de Madrid, estamos hablando de un club cuyo entrenador comenzó su andadura en el equipo en la temporada 2011-12, con lo que durante todo este tiempo ha conseguido crear una plantilla a su deseo, y con ello un grupo de jugadores que se ajustan totalmente a lo que necesita en su plantilla. Todo ello nos indica que estos clubes cuentan con un núcleo de jugadores que desarrollan una larga trayectoria en el club, aportando estabilidad que ayuda al rendimiento deportivo.

Sin embargo, los otros 2 clubes con menor grado medio no obtuvieron resultados positivos. Celta de Vigo y Girona estuvieron durante toda la temporada en las zonas bajas de la tabla, habiéndose mantenido cómodamente en la categoría la temporada anterior. Esto significa que, si bien una estabilidad en la plantilla puede desembocar en resultados positivos, si no se incorporan nuevos jugadores al club, se puede llegar a la situación de que el club obtenga resultados negativos por la complacencia de la plantilla existente.

**Gráfico 5.2. Relación entre grado medio y posición final**




Fuente: elaboración propia

El hecho de contar con un alto nivel de clustering y un grado medio que sea bajo no necesariamente implica que se obtengan éxitos deportivos. Que se creen núcleos dentro de las plantillas también otorga poder a los jugadores dentro del club. Una forma de conocer el poder informal que ostentan es a través del despido de entrenadores.



Durante la temporada 2018-19, 8 clubes decidieron cambiar de entrenador a mitad de temporada, que en cierta medida supone admitir una mala planificación y se debe a malos resultados obtenidos, y en otros casos también influye el poder mencionado. De esos 8 clubes, 4 de ellos están entre los 5 con mayor clustering medio de la competición, es el caso del Celta de Vigo, Athletic Club de Bilbao, Sevilla CF, y SD Huesca. El Real Madrid también decidió cambiar de entrenador con la temporada en curso, mientras que, en otros casos, como el del Villarreal CF, Real Sociedad o Rayo Vallecano los resultados deportivos fueron los principales causantes de esta circunstancia.

**Gráfico 5.3. Clustering medio por equipo**




Fuente: elaboración propia.

Otro factor muy importante a la hora de la concepción de las plantillas de cada club es el presupuesto disponible para su creación. En este sentido, los 3 clubes más grandes son los que más fácil tienen crear un núcleo de jugadores que permanezca durante cierto tiempo, ya que pueden ofrecer tanto posibilidad de éxitos deportivos, como altos sueldos que hagan que pocos clubes intenten contratar a sus jugadores. A nivel estadístico esto se traduce en un grado medio muy bajo, y un nivel de clustering por encima de la media.

En el otro extremo se sitúan aquellos equipos con un bajo presupuesto. Entre ellos destaca una excepción, la SD Huesca, que, a pesar de contar con el segundo presupuesto más bajo de la categoría, tiene un índice de clustering de los más altos, consiguiendo crear un núcleo de jugadores que se ha mantenido en el tiempo, y con el que consiguieron el éxito de ascender a la primera categoría del fútbol español.


Sin embargo, el Rayo Vallecano y el Valladolid CF confirman esta idea, tienen una alta intermediación, así como el Rayo Vallecano cuenta con un nivel de cercanía alto, y el Valladolid CF con un bajo clustering. El ejemplo más representativo es el de la SD Eibar, que cuenta con un nivel de clustering muy bajo, un grado medio, intermediación, y cercanía muy altos. Esto significa que este club, debido a su bajo presupuesto, se ve obligado cada año a confeccionar su plantilla con jugadores que no supongan una alta inversión, jugadores, que, a su vez, se han movido por la competición.

**Gráfico 5.4. Cercanía media por equipo**

Fuente: elaboración propia

A la hora de ver la medida de centralidad de vector propio que valora la centralidad en relación a la centralidad de los nodos colindantes vemos que no existe ninguna relación respecto a otras variables. La red analizada es muy grande y no existe prácticamente correlación entre la centralidad de vector propio, tanto positiva, en el caso de valorar los nodos muy centrales, como negativa, valorando más los nodos poco centrales.


En el sector futbolístico, existen clubes que se conocen como clubes “vendedores”, estos son aquellos que si bien tienen cierta reputación suelen vender sus mejores jugadores y renovar su plantilla constantemente. En España, 2 clubes que toman ese rol son el Sevilla CF y el Valencia CF. Como consecuencia de esta práctica habitual, ambos clubes cuentan con las 2 intermediaciones medias más altas de la competición. Esto, unido a una gestión deportiva eficaz, lleva a ambos clubes a contar con unos presupuestos altos debido a los beneficios que obtienen en la venta de jugadores, y a conseguir sus objetivos deportivos prácticamente cada año.

**Gráfico 5.5. Intermediación media por equipo**

Fuente: elaboración propia

A la vista de los resultados obtenidos en el análisis y teniendo en cuenta tanto el presupuesto como el puesto en que concluyeron la temporada, cabe destacar el papel de 3 equipos, el Getafe CF, la SD Eibar, y el CD Leganés. Los 3 son clubes con presupuestos bajos, que cada año se ven obligados a renovar gran parte de su plantilla, y que rinden a gran nivel a tenor de las expectativas que se podría tener en ellos. Debido a su situación económica, estos clubes cuentan cada año con jugadores cedidos por otros clubes, que generalmente no tienen experiencia en la alta competición, pero que no suponen un coste de traspaso. Cabe destacar el papel del Getafe CF, que concluyó la temporada en 5ª posición, contando con el 14º presupuesto más alto de la competición.


**Gráfico 5.6. Posición final y presupuesto de cada club**



Fuente: elaboración propia

Un caso especial es el del Athletic Club de Bilbao. Este club tiene una política de fichajes única en España que consiste en que solo jugadores bien con antepasados, o nacidos en unas regiones concretas de España y Francia pueden jugar en el club. Esta política conlleva, evidentemente, que el abanico de jugadores disponibles es mucho más reducido que para el resto de equipos. El Athletic Club de Bilbao cuenta en su plantilla de 25 jugadores con 5 jugadores fichados directamente de los clubes que es más probable que sean acordes a su política de fichajes, es decir, los clubes del País Vasco y de Navarra.

Esta movilidad que existe entre esos clubes no ocurre en ninguna de las otras regiones con clubes en la categoría, ni en la Comunidad de Madrid, ni en Cataluña, ni en los equipos de la Comunidad Valenciana. Además, el Athletic Club de Bilbao cuenta con uno de los niveles de clustering más altos de la competición, que es consecuencia directa de su política interna, que le lleva o bien a fichar de otros clubes jugadores con esas características o a desarrollarlos en su propia cantera, que es lo que ocurre en la mayoría de los casos.

**Imagen 5.3. Representación gráfica de la red compuesta por el País Vasco**

Fuente: elaboración propia

### 5.3. RESULTADOS GLOBALES

Al analizar la red en su totalidad, el primer resultado que llama la atención es su excentricidad constante, de valor 3. Esto nos indica que cualquier nodo está a 3 nodos de distancia del nodo que sea el más lejano. Al ser constante, no existen ni nodos muy periféricos, ni muy centrales. Del mismo modo, el diámetro y el radio, ambos toman el valor de 3, ya que al ser la excentricidad constante tanto el menor como el mayor valor de las excentricidades locales es el mismo. El grado medio es de 36,96; lo que significa, de media, haber pasado por 2 equipos, contando con que una plantilla oscila entre los 21 y 25 jugadores y que muchos jugadores o bien se retiran o son traspasados a otras ligas. También ha sido utilizado el clustering global para evaluar la centralidad global, obteniendo un resultado de 0,4951, es decir, existe un 49,51% de probabilidad de que cualquier triángulo de nodos sea cerrado. Es un porcentaje muy alto para tratarse de una red tan grande, aun contando con que la red represente una competición en la que los jugadores están divididos en equipos se trata de una probabilidad muy alta, ya que estamos analizando una red de 459 jugadores. Por último, la distancia media es de 2,21; es decir, la distancia media entre cualquier par de nodos que estén conectados es de 2,21 nodos.

**Tabla 5.2. Resultados globales desglosados**

Excentricidad	3
Diámetro	3
Radio	3
Clustering global	49,51%
Grado medio	36,96
Distancia media	2,21

Fuente: elaboración propia

Como vemos, todas las medidas realizadas sobre toda la red presentan la idea de que la red constituida por los futbolistas de Primera División de la temporada 2018-19 es una

en la que los nodos están muy cerca unos de otros, así como que existe un alto nivel de clustering, propio, como hemos dicho, de una red en la que cuyos miembros están concentrados en equipos. En la misma línea, el hecho de que la excentricidad sea constante indica que no hay ningún nodo alejado del resto. Por ende, la red en su totalidad no está centralizada en ninguna zona concreta.

A tenor de todos los resultados, vemos en primer lugar que los jugadores más centrales se repiten con todas las distintas formas de medición utilizadas, y que, de forma general, el perfil de jugador con mayor centralidad es aquel con una dilatada trayectoria en la categoría.

A nivel de equipos, existe una relación directa entre los 3 grandes equipos de España y su centralidad. El poder informal que se atribuye a los jugadores se aprecia en el estudio con el caso de cambios de entrenador durante la temporada. La relación entre el presupuesto del club y su centralidad también es directa, como se ve con el caso de los 3 clubes más grandes y también los recién ascendidos. A su vez, las distintas filosofías de gestión deportiva se ven reflejadas, en el caso del Sevilla CF y el Valencia CF con una alta intermediación fruto de su constante renovación de plantilla, y en el caso de la SD Eibar con una alta participación en la red. Como casos llamativos cabe destacar el del Getafe CF, que con uno de los presupuestos más bajos de la categoría consiguió un rendimiento extraordinario, y el del Athletic Club de Bilbao, cuya política de fichajes se ve reflejada a nivel estadístico.

La red en su totalidad está ciertamente muy conectada. El hecho de que los jugadores estén agrupados en jugadores ayuda, pero no por ello es menos destacable que es una red en la que no hay jugadores ni muy alejados ni muy centrales.

## 6. CONCLUSIONES

El fútbol es un sector muy importante en la sociedad española. Su influencia es muy grande en muchos aspectos, genera un gran impacto económico tanto de forma directa como indirecta, y además lleva consigo un impacto social contra el que casi nada puede competir, no solo en España, sino en todo el planeta.

En este trabajo han sido analizadas variables totalmente objetivas, como es la trayectoria de cada uno de los 459 jugadores de Primera División del fútbol español, y con ellas crear la red con la que se ha analizado la centralidad en distintos niveles.

La importancia económica del estudio es muy clara, solo se puede comparar con otros deportes para encontrar casos en los que un grupo de trabajadores, que no sean de alta dirección, acaparen una suma del presupuesto tan grande como en este caso. Incluso los equipos que menos dinero destinan a sus plantillas lo hacen en una suma muy importante en niveles cuantitativos.

Los resultados, en líneas generales, indican algo lógico, como es que los jugadores más veteranos hayan coincidido con un número mayor de jugadores y tengan una posición más central en la red que otros más jóvenes. Una gran diferencia respecto a hacer este mismo análisis con los Recursos Humanos de cualquier otra industria es el hecho de que en el fútbol es muy común la práctica de ceder jugadores, en la que un equipo cede un jugador a otro equipo por un tiempo acordado entre ellos, y al llegar al final de ese tiempo el jugador vuelve a su club de origen, a no ser que los clubes hayan acordado una opción de compra o el club de origen tome otra decisión respecto al jugador.

Esto hace que los equipos pequeños suelen recurrir a las cesiones, ya que solamente deben hacerse cargo del salario del jugador, y en algunas ocasiones, el club de origen desembolsa una parte de su salario. Que las cesiones sean tan comunes hace que jugadores como Munir y Cheryshev, que son relativamente jóvenes con una larga carrera por delante, ocupen una posición central en la red. Lo mismo ocurre con Rubén Sobrino, que encaja en ese mismo perfil.

Una limitación de este estudio, si bien no lo es del todo, es el hecho de que abarca 1 temporada concreta y solamente 1 competición. Si bien el objetivo del estudio es claro y se ha conseguido, para poder obtener un resultado aún más completo lo óptimo sería contar con los datos de muchas más competiciones y muchos más futbolistas para poder crear una red quizá no a nivel mundial, pero al menos a nivel europeo, ya que, si la globalización es un hecho en el mundo, en el fútbol lo es desde hace más de 2 décadas. Del mismo modo, entiendo que el potencial de este estudio es muy grande. Al estudiar trabajadores, y, por tanto, personas, podríamos incluir muchísimas variables que nos permitan profundizar en el análisis, como son la edad, el tiempo en la élite, si juegan en su país de origen o no, etc. En resumen, existen infinitas variables y de datos que podrían ser analizados, e incluso ser utilizados a nivel competitivo, siendo una herramienta tecnológica más utilizada en la competición.

Por último, a nivel personal, me he enfrentado a retos a los que jamás me había enfrentado, como por ejemplo utilizar programas informáticos que no conocía o aprender conceptos que nunca había estudiado. En el proceso de realización del trabajo mi concepción sobre el deporte ha cambiado, y cada vez que veo un partido de fútbol no puedo no pensar en este trabajo y en las posibilidades que tiene. Además, el hecho de que sea aficionado al deporte ha hecho que tuviera unas ideas previas sobre cuáles podían ser los resultados, que, evidentemente, al obtener, no tenían relación alguna con

mis expectativas, y que, al analizar, tuve que atenerme estrictamente a los resultados obtenidos.

Hasta donde yo conozco, la teoría de redes se ha utilizado en el fútbol para evaluar más directamente el juego en sí, analizando cómo se estructuran los pases en un partido, pero no para evaluarlo desde la perspectiva de los Recursos Humanos. Esto me ha otorgado una libertad para realizar un trabajo que considero novedoso en su ámbito, y que para mí ha sido una experiencia ciertamente positiva.

## 7. BIBLIOGRAFÍA

- BULDÚ, JM [et al.]. 2019. Defining a historic football team: Using Network Science to analyse Guardiola's FC Barcelona. Scientific Reports. **9**, 13602. Disponible en: <https://www-nature-com.unican.idm.oclc.org/articles/s41598-019-49969-2>
- Consejo Superior de Deportes. 2019. Balance de la situación económico-financiera del fútbol español 1999/2018. [Consulta: 5-11-2019]. Disponible en: <https://www.csd.gob.es/sites/default/files/media/files/2019-05/BALANCE%20SITUACI%C3%93N%20F%C3%9ATBOL%201999-2018.pdf>
- CORDÓN GARCÍA, O. 2007. Tema 3: Redes sociales. Centralidad. [material didáctico] En: *Universidad de Granada*. [Consulta: 30-3-2019] Disponible en: <https://sci2s.ugr.es/sites/default/files/files/Teaching/GraduatesCourses/RedesSistemasCompejos/Tema03-RedesSociales-13-14.pdf>
- Datacamp. 2018. Network analysis in R: Centrality measures. [Consulta:10-12-2019]. Disponible en: <https://www.datacamp.com/community/tutorials/centrality-network-analysis-R>
- Europapress. 2018. La industria de los videojuegos factura 1530 millones de euros en España durante 2018. [Consulta: 7-11-2019]. Disponible en: <https://www.europapress.es/portaltic/videojuegos/noticia-industria-videojuegos-factura-1530-millones-euros-espana-2018-20190507115604.html>
- FC Barcelona. 2019. El Barça superará los mil millones de ingresos, un año antes de lo previsto, y se consolida como líder en ingresos de los clubes deportivos del mundo. [Consulta: 5-11-2019]. Disponible en: <https://www.fcbarcelona.es/es/noticias/1349380/el-barca-superara-los-mil-millones-de-ingresos-un-ano-antes-de-lo-previsto-y-se-consolida-como-lider-en-ingresos-de-los-clubes-deportivos-del-mundo>
- FIFA. 2018. Más de la mitad del planeta disfrutó de un Mundial incomparable en 2018. [Consulta: 8-11-2019]. Disponible en: <https://es.fifa.com/worldcup/news/mas-de-la-mitad-del-planeta-disfruto-de-un-mundial-incomparable-en-2018>
- Forbes. 2019. Sports Agents. [Consulta: 7-11-2019] Disponible en: <https://www.forbes.com/sports-agents/list/>
- Impulsapopular. 2014. ¿Qué porcentaje de los ingresos brutos de tu empresa deben gastarse en salarios? [Consulta: 6-11-2019]. Disponible en: <https://www.impulsapopular.com/finanzas/que-porcentaje-de-los-ingresos-brutos-de-tu-empresa-deben-gastarse-en-salarios/>
- KORTE, F [et al.]. 2019. Play-By-Play network analysis in football. *Frontiers in Psychology*. **10**. ISSN: 1664-1078. Disponible en: <https://www.frontiersin.org/articles/10.3389/fpsyg.2019.01738/full>
- Pricewaterhousecoopers. 2018. Impacto económico, fiscal y social del fútbol profesional en España. [Consulta: 10-11-2019]. Disponible en: <https://www.pwc.es/es/publicaciones/entretenimiento-y-medios/assets/informe-impacto-socioeconomico-laliga-2016-17.pdf>
- Primetimesport. 2019. Football Transfer Review. [Consulta: 7-11-2019]. Disponible en: [http://www.primetimesport.com/images/FTR/2019/Football\\_Transfer\\_Review\\_2019\\_20\\_by\\_Prime\\_Time\\_Sport\\_LaLiga\\_compressed-2.pdf](http://www.primetimesport.com/images/FTR/2019/Football_Transfer_Review_2019_20_by_Prime_Time_Sport_LaLiga_compressed-2.pdf)
- Transfermarkt. 2020. [Consulta: 19-1-2020]. Disponible en: <https://www.transfermarkt.es/>



- Vozpopuli. 2019. Las comisiones de los clubes españoles a agentes de futbolistas se disparan un 300% en 2019. [Consulta: 8-11-2019]. Disponible en: [https://www.vozpopuli.com/economia-y-finanzas/comisiones-clubes-espanoles-agentes-futbolistas\\_0\\_1285971717.html](https://www.vozpopuli.com/economia-y-finanzas/comisiones-clubes-espanoles-agentes-futbolistas_0_1285971717.html)